### PATENT ABSTRACTS OF JAPAN

(11) Publication number: 11238053 A

(43) Date of publication of application: 31 . 08 . 99

(51) Int. CI

G06F 17/21 G06F 17/24

(21) Application number: 10041644

(22) Date of filing: 24 . 02 . 98

(71) Applicant:

MATSUSHITA ELECTRIC IND CO

LTD

(72) Inventor:

**IKUTA JUNZO** 

**NUMATA YASUYUKI** 

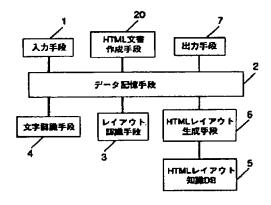
(54) DOCUMENT DEVICE, DOCUMENT
GENERATION METHOD AND RECORDING
MEDIUM RECORDING DOCUMENT
GENERATION PROGRAM

### (57) Abstract:

PROBLEM TO BE SOLVED: To convert an existed document inputted as picture data into a document described by prescribed structured tag language.

SOLUTION: Picture data inputted from an input means 1 is layout-recognized by a layout recognition means 3 and an HTML layout generation means 6 generates the control code of HTML based on respective recognized layouts and HTML(hyper text mark up language) layout knowledge 5. A character recognition means 4 character-recognizes input picture data and outputs a character code. An HTML document generation means 20 generates the HTML document by associating the control code of HTML with the character code and outputs it from an output means 7.

COPYRIGHT: (C)1999,JPO



# (19)日本国特許庁(J P)

17/24

# 四公開特許公報(A)

### (11)特許出願公期番号

# 特開平11-238053

(43)公開日 平成11年(1999)8月31日

(51) Int.Cl.<sup>6</sup>
G 0 6 F 17/21

餓別配号

FI

G06F 15/20

530A

534P

# 審査請求 未請求 請求項の数5 OL (全 10 頁)

(21)出願番号

特顯平10-41644

(22)出顧日

平成10年(1998) 2月24日

(71)出額人 000005821

松下電器産業株式会社

大阪府門真市大字門真1006番地

(72)発明者 生田 淳三

大阪府門真市大字門真1006番地 松下電器

産業株式会社内 .

(72)発明者 招田 泰之

大阪府門真市大字門真1006番地 松下電器

産業株式会社内

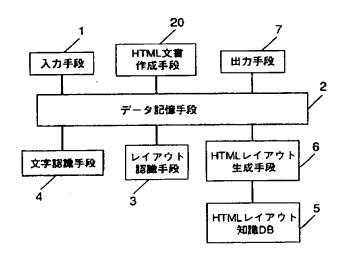
(74)代理人 弁理士 掩本 智之 (外1名)

# (54) 【発明の名称】 文書作成装置および文書作成方法ならびに文書作成プログラムを記録した記録媒体

### (57) 【要約】

【課題】 画像データとして入力される既存の文書を、 所定の構造化タグ言語で記述された文書に変換するこ と

【解決手段】 入力手段1から入力される画像データを、レイアウト認識手段3によりレイアウト認識し、認識された各レイアウトとHTMLレイアウト知識DB5とに基づいて、HTMLレイアウト生成手段6によりHTMLの制御コードを生成する。また、文字認識手段4は入力画像データを文字認識して文字コードを出力し、HTML文書作成手段20は、HTMLの制御コードと文字コードとを関連付けてHTML文書を作成し、出力手段7より出力する。



### 【特許請求の範囲】

【請求項1】 画像データとして入力される文書から、所定の構造化タグ目語で記述された文書を作成する文書作成装置であって、

文哲を画像データとして入力する入力手段と、

前記入力手段から入力される画像データを記憶する入力 画像記憶手段と、

入力画像記憶手段に記憶される画像データのレイアウト を認識するレイアウト認識手段と、

構造化タグ昏語のレイアウトに関する変換ルールを記憶 10 したレイアウト知識記憶手段と、

前配レイアウト知識配億手段の変換ルールに基づいて、 前配レイアウト認識手段により認識される各レイアウト に対して構造化タグ言語の制御コードを生成する制御コ ード生成手段と

前記入力画像記憶手段に記憶される画像データ中の文字 イメージを認識し、文字コードに変換する文字認識手段 と、

前記文字認識手段により出力される文字コードと、前記 制御コード生成手段により生成される制御コードとを関 連付けて、構造化タグ言語で記述された文書を作成する 文書作成手段と、

前記文書作成手段により作成された文書を出力する出力 手段と、を有することを特徴とする文書作成装置。

【請求項2】前記レイアウト知識配億手段は、利用者により変換ルールを追加可能であることを特徴とする請求項1に記載の文書作成装置。

【請求項3】前記文書作成手段は、複数の入力画像データから得られる各文書を連結し、1 つの構造化タグ言語で記述された文書として生成することを特徴とする請求項1記載の文書作成装置。

【請求項4】画像データとして入力される文書から、所定の構造化タグ言語で記述された文書を作成する文書作成方法であって、

入力される画像データを記憶するステップと、

入力される画像データのレイアウトを認識するステップ と、

構造化タグ言語のレイアウトに関する変換ルールを参照 し、認識される各レイアウトに対して構造化タグ言語の 制御コードを生成するステップと、

入力される画像データ中の文字イメージを認識し、文字 コードに変換するステップと、

変換された文字コードと、生成された制御コードとを関連付けて、構造化タグ言語で記述された文書を作成する ステップと、

作成された文書を出力させるステップと、を有すること を特徴とする文書作成方法。

【請求項5】 画像データとして入力される文書から、所 定の構造化タグ言語で記述された文書を作成する文書作 成プログラムを記録した記録媒体であって、 入力される画像データを記憶するステップと、

入力される画像データのレイアウトを認識するステップ レ

構造化タグ言語のレイアウトに関する変換ルールを参照 し、認識される各レイアウトに対して構造化タグ言語の 制御コードを生成するステップと、

入力される画像データ中の文字イメージを認識し、文字 コードに変換するステップと、

変換された文字コードと、生成された制御コードとを関 連付けて、構造化タグ言語で記述された文書を作成する ステップと、

作成された文書を出力させるステップと、を有すること を特徴とする文書作成プログラムを記録した記憶媒体。

### 【発明の詳細な説明】

### ~~ [0001]

【発明の属する技術分野】本発明は、例えばインターネット(Internet)上で、ワールド・ワイド・ウェブ(World Wide Web)のホームページを記述するための言語であるHTML(HyperText Markup Language)など、構造化タグ言語で記述された文書を作成する文書作成装置および文書作成方法ならびに文書作成プログラムを記録した記録媒体に関するものである。

### [0002]

【従来の技術】テキストファイル中にタグと呼ばれる文字列(制御コード)を置くことで、文字の配置、大きさ、使用フォントなどを指定することのできる構造化タグ言語が知られている。構造化タグ言語で記述された文書は、ブラウザと呼ばれる専用のプログラムを用いることにより、文書に記述されている制御コードに従って表30示される。

【0003】この構造化タグ言語の代表的なものとして、インターネット上のWWWのホームページを記述する言語であるHTMLが知られている。特に、近年のインターネット技術やイントラネット技術の発達ならびに普及により、様々な文書をHTML文書に変換する要求が高まっている。当然ながら、従来より保持している紙に印字された膨大な文書をHTML文書の形式に変換して利用したいという要求も大きい。

【0004】紙に印字された文書をHTML文書のよう 40 な構造化タグ言語で記述された文書に変換する場合に は、次の2つの方法がある。1つ目の方法は、文書を光 学式スキャナ装置で読み取り、それをそのままイメージ データとしてHTML文書内に組み込んで利用する方法 である。2つ目の方法は、文書を見ながら人手でHTML用の制御コードを付与していく方法である。

### [0005]

【発明が解決しようとする課題】しかしながら、従来の方法では次のような問題点がある。まず、イメージデータとして利用する場合には、イメージデータが巨大になり、記憶する容量やユーザが閲覧するためにデークを取

得する時間が巨大になるという問題点がある。また、人 手でHTML用の制御コードを付与する場合には、膨大 な作業時間を必要とし、効率的ではない。

【0006】本発明は、画像データとして入力される既存の文書を、所定の構造化タグ言語で記述された文書に変換することのできる文書作成装置および文書作成方法ならびに文書作成プログラムを記録した記録媒体を提供することを目的とする。

### [0007]

【課題を解決するための手段】この課題を解決するため に本発明は、画像データとして入力される文書から、所 定の構造化タグ言語で記述された文書を作成する文書作 成装置であって、文書を画像データとして入力する入力 手段と、入力手段から入力される画像データを記憶する 入力画像記憶手段と、入力画像記憶手段に記憶される画 像データのレイアウトを認識するレイアウト認識手段 と、構造化タグ言語のレイアウトに関する変換ルールを 記憶したレイアウト知識記憶手段と、レイアウト知識記 憶手段の変換ルールに基づいて、レイアウト認識手段に より認識される各レイアウトに対して構造化タグ言語の 制御コードを生成する制御コード生成手段と、入力画像 記憶手段に記憶される画像データ中の文字イメージを認 識し、文字コードに変換する文字認識手段と、文字認識 手段により出力される文字コードと、制御コード生成手 段により生成される制御コードとを関連付けて、構造化 タグ言語で記述された文書を作成する文書作成手段と、 文書作成手段により作成された文書を出力する出力手段 と、を有する構成とした。

【0008】これにより、画像データとして入力される 既存の文書を、所定の構造化タグ官語で記述された文書 に変換することのできる文書作成装置が得られる。

### [0009]

【発明の実施の形態】本発明の請求項1に記載の発明 は、画像デークとして入力される文書から、所定の構造 化タグ目語で記述された文書を作成する文書作成装置で あって、文書を画像データとして入力する入力手段と、 入力手段から入力される画像データを記憶する入力画像 記憶手段と、入力画像記憶手段に記憶される画像データ のレイアウトを認識するレイアウト認識手段と、構造化 タグ言語のレイアウトに関する変換ルールを記憶したレ イアウト知識記憶手段と、レイアウト知識記憶手段の変 換ルールに基づいて、レイアウト認識手段により認識さ れる各レイアウトに対して構造化タグ言語の制御コード を生成する制御コード生成手段と、入力画像記憶手段に 記憶される画像データ中の文字イメージを認識し、文字 コードに変換する文字認識手段と、文字認識手段により 出力される文字コードと、制御コード生成手段により生 成される制御コードとを関連付けて、構造化タグ言語で 記述された文書を作成する文書作成手段と、文書作成手 段により作成された文書を出力する出力手段と、を有す 50 4

る構成としたことにより、画像データとして入力される 文書のレイアウトに従って、所定の構造化タグ言語の制 御コードを付与し、構造化タグ言語で記述された文書に 変換することができる。

【0010】本発明の請求項2に配載の発明は、請求項1に記載の発明において、レイアウト知識記憶手段は、利用者により変換ルールを追加可能である構成としたことにより、利用者の持つ文書に特有の表現に対応できる。

10 【0011】本発明の請求項3に記載の発明は、請求項 1に記載の発明において、文書作成手段は、複数の入力 画像データから得られる各文書を連結し、構造化タグ目 語で記述された1つの文書として生成する構成としたこ とにより、物理的に複数のページにわたる文書であって も、構造化タグ目語で記述された1つのページとして利 用できる。

【0012】以下、本発明の実施の形態について、図面を参照しながら説明する。なお、以下の各実施の形態では、構造化タグ書語の具体例として、HTMLを例にとり説明を行っている。

【0013】(実施の形態1)図1は本発明の第1の実施の形態における文書作成装置の機能プロック図であり、機能手段による構成を示している。

【0014】図1において、1は画像イメージを入力する入力手段、2は画像イメージやレイアウト認識、文字認識結果などを記憶するデータ記憶手段、3は入力された画像イメージのレイアウトを認識するレイアウト認識手段、4は文字イメージを文字コードに変換する文字認識手段と、5はHTMLレイアウトに関する変換ルールを記憶したHTMLレイアウト知識DB5にしたがって、HTMLの制御コードを生成するHTMLレイアウト生成手段、7は作成されたHTML文書をファイル等に保存したりディスプレイに表示したりする出力手段、20は文字認識手段4より出力される文字コードと、HTMLレイアウト生成手段6により生成された制御コードとを関連付けてHTML文書を作成するHTML文書作成手段である。

【0015】図2は本発明の第1の実施の形態における 40 文書作成装置の装置ブロック図であり、ハードウェアに よる構成を示している。

【0016】図2において、8はデータを読み込むスキャナである。9は制御プログラムを実行することにより装置を制御する中央処理演算装置(CPU)である。10はデータを記憶するリード・オンリー・メモリ(ROM)であり、CPU9が実行するプログラムを格納する領域を有する。11はデークを一時的に記憶するランダム・アクセス・メモリ(RAM)である。12は陰極線管ディスプレイ(CRT)などの表示装置である。

【0017】13はフロッピー・ディスク(FD)など

レイアウト生成の動作フローチャートである。

の記録媒体にデータを読み書きするディスク・ドライブ である。14はキーボードやポインティング・デバイス などの入力装置、15はハード・ディスクなどの2次記 億装置である。16はデータ・バスである。

【0018】ここで、図1の機能手段と図2のハードウェアとの対応関係を説明する。図1および図2に示すように、入力手段1はスキャナ8により実現される。データ記憶手段2はRAM11により実現される。HTMLレイアウト知識DB5はROM10あるいは2次記憶装置15により実現される。出力手段7はCRT12あるいはディスク・ドライブ13により実現される。

【0019】レイアウト認識手段3、文字認識手段4、 HTMLレイアウト生成手段6は、CPU9がROM1 0およびRAM11とデータのやりとりを行いながらR OM10に記憶されている制御プログラムを実行することにより実現される。

【0020】なお、本実施の形態では、CPU9はROM10に格納された制御プログラムを実行する形態を示しているが、記録媒体17からディスク・ドライブ13を介して制御プログラムを読み込み、RAM11あるいは2次記憶装置15に展開したものをCPU9が実行する形態としても良い。このような形態とすることにより、本発明を汎用コンピュータでも容易に実現可能とすることができる。

【0021】以上のように構成された文書作成装置について、以下にその動作について説明する。なお、以下のフローチャートは、CPU9がROM10に格納されている制御プログラムを実行する様子について示したものである。

【0022】図3は本発明の第1の実施の形態における 文書作成装置の動作フローチャートである。

【0023】図3に示すように、まず、入力手段1から 画像が入力され、入力される画像データをデータ記憶手 段2に記憶させる(ステップ1)。ここでは、図5に示 す画像が入力されたものとする。

【0024】次に、レイアウト認識手段3は、入力された画像イメージの解析を行い、レイアウトの認識を行う(ステップ2)。ここでは、文字領域が大きく2つに分れ、「我が家のレシピ集」がセンタリングされ、比較的大きな文字で書かれていること、および「昨日のメニュー」から続く3行が箇条書きされていることが認識される。なお、ここで「我が家のレシピ集」という書き方を行ったが、まだ文字認識は行われておらず、現時点では「我が家のレシピ集」という文字列が生成されているわけではなく、そこにあるイメージの部分のことを示している。

【0025】HTMLレイアウト生成手段6は、HTM Lレイアウトの生成を行う(ステップ3)。このステップ3は、図4を使って詳しく説明する。

【0026】図4は本発明の第1の実施の形態における

【0027】図4に示すように、まず、ステップ301では、HTMLレイアウト生成手段6は、HTMLレイアウト知識DB5より、1つのルールを取り出す。図6にHTMLレイアウト知識DB5の例を示す。ここでは、「センタリングされている大きな文字→〈CENTER〉〈H1〉と、〈/H1〉〈/CENTER〉で囲む」が取り出される。

【0028】次に、ステップ302では、HTMLレイアウト生成手段6は、レイアウト認識手段3が出力したレイアウト情報を参照し、取り出したルールに合致するレイアウトがあるかどうか調べる。ここでは、「我が家のレシピ集」の部分がルールに一致するのでステップ303へ進む。

【0029】ステップ303では、ルール中の「→」以降の処理がなされ、「我が家のレシピ集」の部分が、〈CENTER〉で囲むことがデータ記憶手段2に記憶される。

【0030】ステップ302に戻り、再度、ルールに合致するレイアウトがあるかどうか調べる。ここでは存在しないので、ステップ304に進む。

【0031】ステップ304では、HTMLレイアウト 生成手段6は、HTMLレイアウト知識DB5に記憶さ れているルールのうち、全てのルールの処理を行ったか どうか調べる。図6に示すルールのうち、まだ1つしか 処理を終えていないのでステップ301に戻る。

【0032】ステップ301では、HTMLレイアウト 生成手段6は、HTMLレイアウト知識DB5より、別 のルールを取り出す。図6にHTMLレイアウト知識D B5の例を示す。ここでは、「箇条書きになっている部 30 分→全体を〈UL〉と〈/UL〉で囲み、それぞれの項目を〈LI〉 と〈/LI〉で囲む」が取り出される。

【0033】ステップ302では、HTMLレイアウト生成手段6は、レイアウト認識部3が出力したレイアウト情報を参照し、ルールに合致するレイアウトがあるかどうか調べる。ここでは、「昨日のメニュー」から「明日のメニュー」までが箇条書き部分であるので、ルールに一致し、ステップ303へ進む。

【0034】ステップ303では、ルールの「→」以降の処理がなされ、「昨日のメニュー」から「明日のメニ 40 ュー」までの全体を〈UL〉と〈/UL〉で囲み、また、「昨日のメニュー」、「今日のメニュー」、「明日のメニュー」をそれぞれ〈LI〉と〈/LI〉で囲むことがデータ記憶手段2に記憶される。

【0035】ステップ302に戻り、再度、ルールに合 致するレイアウトがあるかどうか調べる。ここでは存在 しないので、ステップ304に進む。

【0036】ステップ304では、HTMLレイアウト 生成手段6は、HTMLレイアウト知識DB5に記憶さ れているルールのうち、全てのルールの処理を行ったか 50 どうか調べる。ここでは全てのルールの処理が終わった

ものとして、ステップ305へ進む。

【0037】ステップ305では、処理されていないレ イアウトが存在するか調べる。ここでは全てのルールが 試されたが、処理されていないレイアウトが存在した場 合は、ステップ306に示すごとく、レイアウト処理が できない部分があったことを出力手段7に出力する。

【0038】なお、ステップ306で警告を表示する代 わりに、何らかのデフォルト的な処理を行ってもよい。 例えば、全ての文字を本文のデータとして何のレイアウ データはコメントとして挿入する、などである。

【OO39】以上で、図4に示すHTMLレイアウト生 成が終了するので、図3に戻りステップ4に進む。

【0040】図3に戻り、入力画像データの文字認識を 行う (ステップ4)。ステップ4では、各文字領域の文 字を認識し、文字コードを出力する。文字コードが出力 されると、HTML文書作成手段20は、ステップ3で 生成したHTMLレイアウト情報に従って文字コードを 埋め込み、HTML文書を作成する(ステップ5)。ス テップ5では、さらに、HTML文書であることの必須 20 の制御コードとして、文書の先頭に〈HTML〉〈BODY〉を、ま た文書の最後に</BODY></HTML>をそれぞれ付与する。

【OO41】作成されたHTML文書は、出力手段7に より出力される。全てのデータが出力手段?に出力され ている状態を図7に示す。この出力は、例えば、ディス ク・ドライブ13に保存したり、表示装置12に表示し たりすることである。

【0042】以上のように本実施の形態によれば、入力 される画像データのレイアウト認識を行い、レイアウト 認識した結果に基づいて、HTMLの制御コードを生成 30 し、さらに、文字認識した結果と前記制御コードを関連 付けることで、HTML文書を作成するので、操作者 は、既存の文書をHTML文書に変換する際、制御コー ドを手動で付与する必要がなくなり、作業の効率化を図 ることができる。

【0043】 (実施の形態2) 以下、本発明の第2の実 施の形態について説明する。

【0044】本実施の形態では、第1の実施の形態に示 すHTMLレイアウト知識DB5に利用者が必要に応じ てルールを追加・修正することができるようにするもの 40 である。

【0045】例えば、図8に示すように、罫線で囲まれ た3段組の表を含んだ文書をHTML文書化する場合、 HTMLレイアウト知識DB5に、罫線で書かれた3段 組の表を処理するルールが存在しないとする。

【0046】このような場合、操作者は、キーボードな どの入力装置を用い、図9に示すように、HTMLレイ アウト知識DB5に新たなルールを追加することによ り、第1の実施の形態で示した手順により図10に示す HTML文書を得ることができる。

【0047】以上のように本実施の形態では、このよう にしてHTMLレイアウト知識DB5に用意していなか ったようなレイアウトを持つ文書に対しても、操作者が ルールを追加・修正することによりHTML文書を自動 的に作成することができる。

【0048】 (実施の形態3) 以下、本発明の第3の実 施の形態について説明する。

【0049】本実施の形態では、第1の実施の形態で示 した文書作成装置において、入力される文書の複数のペ ト情報なしに利用する、レイアウトが確認できなかった 10 ージを、1 つのHTML文書として処理できるようにす るものである。

> 【0050】図11は本発明の第3の実施の形態におけ る文書作成装置の動作フローチャートである。

> 【0051】図11に示すように、入力手段1より複数 の画像データが入力され、データ記憶手段2に記憶され る(ステップ501)。

> 【0052】入力された画像データは、第1の実施の形 態に示したステップ2~ステップ5の手順、すなわち、 図3に示す手順により、HTML文書に変換される(ス テップ502)。

> 【0053】この手順を、全てのページが処理されるま で続ける(ステップ503)。ここでは図12に示す2 ページの文書をHTML文書化することを例に取り説明 すると、図13に示すように、それぞれのページがHT ML文書化される。

> 【0054】次に、HTML文書作成手段20は、複数 ページの結合処理を行う(ステップ504)。具体的に は、それぞれのページ間の〈HTML〉〈BODY〉および〈/BODY〉〈 /HTML>を削除して、それぞれのページをつなげる。その 結果を図14に示す。

【0055】作成されたHTML文書は、出力手段7よ り出力される(ステップ505)。この出力は、例え ば、ディスク・ドライブ13に保存したり、表示装置1 2に表示したりすることである。

【0056】以上のように本実施の形態によれば、論理 的には1つながりのページで、用紙の都合上複数ページ に分割されているため、入力される画像データが複数に 分かれている場合でも、1つのHTML文書として作成 することが可能となる。

【0057】以上、各実施の形態ではある形態を例にと って説明を行ったが、本発明は、上記した各実施の形態 のみにとどまらないことは言うまでもない。例えば、入 力手段1としてスキャナ8を例にとり説明したが、スキ ャナ8から入力するのではなく、画像データをディスク ・ドライブ13やネットワークを介して入力する場合も 考えられる。

【0058】また、出力結果を記憶媒体17に出力する 例を説明したが、フラッシュ・メモリカードや、ネット ワークを介した他のデバイスへ出力することなども考え 50 Sha.

[0059]

【発明の効果】以上のように本発明によれば、画像デー タとして入力される文書から、所定の構造化タグ目語で 記述された文書を作成する文書作成装置であって、文書 を画像データとして入力する入力手段と、入力手段から 入力される画像データを記憶する入力画像記憶手段と、 入力画像記憶手段に記憶される画像データのレイアウト を認識するレイアウト認識手段と、構造化タグ目語のレ イアウトに関する変換ルールを記憶したレイアウト知識 記憶手段と、レイアウト知識記憶手段の変換ルールに基 10 ータを示す図 づいて、レイアウト認識手段により認識される各レイア ウトに対して構造化タグ官語の制御コードを生成する制 御コード生成手段と、入力画像記憶手段に記憶される画 俊データ中の文字イメージを認識し、文字コードに変換 する文字認識手段と、文字認識手段により出力される文 字コードと、制御コード生成手段により生成される制御 コードとを関連付けて、構造化タグ官語で記述された文 掛を作成する文書作成手段と、文書作成手段により作成 された文書を出力する出力手段と、を有する構成とした ことにより、画像データとして入力される文書のレイア 20 のHTML文書を示す図 ウトに従って、所定の構造化タグ言語の制御コードを付 与し、構造化タグ言語で記述された文書に変換すること ができるので、変換作業における操作者の操作負担が軽 滅される。

【0060】また、レイアウト知識記憶手段は、操作者 により変換ルールを追加可能である構成としたことによ り、利用者の持つ文書に特有の表現に対応でき、以後の 変換精度を向上させることができる。

【0061】また、文書作成手段は、複数の入力画像デ ータから得られる各文書を連結し、構造化タグ言語で記 30 7 出力手段 述された1つのHTML文書として生成する構成とした ことにより、物理的に複数のページにわたる文書であっ ても、構造化タグ言語で記述された1つのページとして 利用でき、変換後の利用効率化を図ることができる。

### 【図面の簡単な説明】

【図1】本発明の第1の実施の形態における文書作成装 置の機能プロック図

【図2】本発明の第1の実施の形態における文書作成装 置の回路ブロック図

【図3】本発明の第1の実施の形態における文書作成装 40 20 HTML文書作成手段 置の動作フローチャート

【図4】本発明の第1の実施の形態におけるレイアウト 生成の動作フローチャート

【図5】本発明の第1の実施の形態における入力画像デ ータを示す図

【図6】本発明の第1の実施の形態におけるHTMLレ イアウト知識DBを示す図

【図7】本発明の第1の実施の形態における作成された HTML文書を示す図

【図8】本発明の第2の実施の形態における入力画像デ

【図9】本発明の第2の実施の形態におけるHTMLレ イアウト知識DBを示す図

【図10】本発明の第2の実施の形態における作成され たHTML文書を示す図

【図11】本発明の第3の実施の形態における文書作成 装置の動作フローチャート

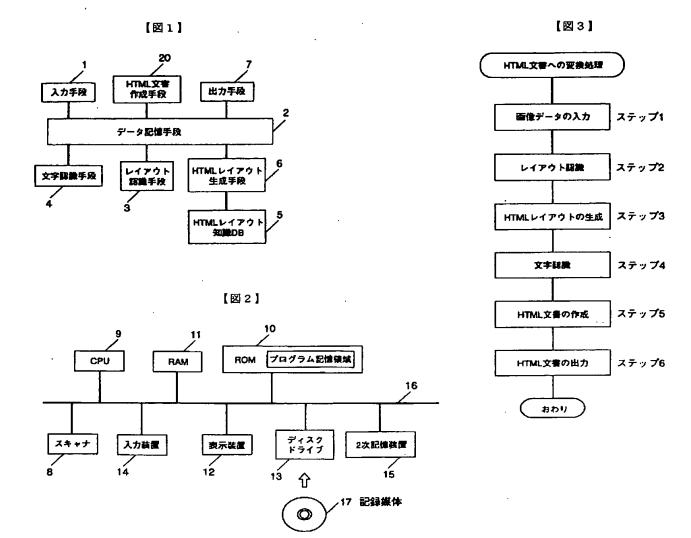
【図12】本発明の第3の実施の形態における入力画像 データを示す図

【図13】 本発明の第3の実施の形態における処理途中

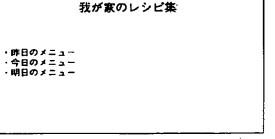
【図14】本発明の第3の実施の形態における作成され たHTML文書を示す図

### 【符号の説明】

- 1 入力手段
- 2 データ記憶手段
- 3 レイアウト認識手段
- 4 文字認識手段
- 5 HTMLレイアウト知識DB
- 6 HTMLレイアウト生成手段
- - 8 スキャナ
  - 中央処理装置(CPU)
  - 10 リード・オンリー・メモリ (ROM)
  - 11 ランダム・アクセス・メモリ (RAM)
  - 12 表示装置
  - 13 ディスク・ドライブ
  - 14 入力装置
  - 15 2次記憶装置
  - 16 データ・バス



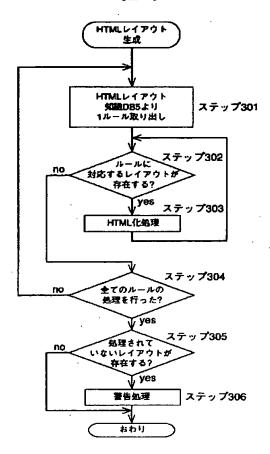
【図5】



[図6]

・センタリングされている大きな文字
→ (CENTER) 〈HI)と〈/HI〉〈/CENTER〉で囲む
・箇条書きになっている部分
→全体を(UL)と〈/UL〉で囲み、
それぞれの項目を〈LI〉と〈/LI〉で囲む。

【図4】



[図8]

# 我が家のレシピ集 | 肉を使ったメニュー | 魚を使ったメニュー | 野菜を使ったメニュー | 小昨日のメニュー | ・・今日のメニュー | ・・・ 中日のメニュー | ・・ 明日のメニュー |

### 【図7】

```
(HTML)
(BODY)
(CENTER) (HI) 投が家のレシピ集〈/HI〉 (/CENTER〉

(UL)
(U) 昨日のメニュー (/U)
(U) 今日のメニュー (/U)
(U) 明日のメニュー (/U)
(バル)
(/BODY)
(/HTML)
```

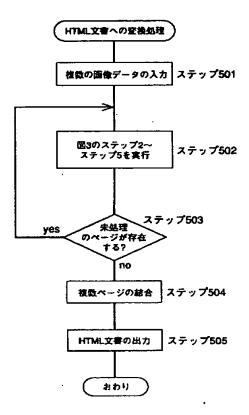
### 【図9】

```
・センタリングされている大きな文字
→ 〈CENTER〉〈HI〉と〈/HI〉〈/CENTER〉で囲む
・ 簡条書きになっている部分
→全体を〈UI、〉と〈/UL〉で囲み、
それぞれの項目を〈LI〉と〈/LI〉で囲む。
・ 野線で囲まれた3段組の表
→全体を〈TABLE BORDER COLS=3〉〈TR〉と
〈/TR〉〈/TABLE〉で囲み、
それぞれの項目を〈TD〉と〈/TD〉で囲む。
```

# 【図10】

```
(HTML)
(BODY)
(CENTER) (HI) 我が家のレシピ集〈/HI〉 (/CENTER)
(TABLE BORDER COLS=3) 〈TR)
(TD) 内を使ったメニュー (/TD)
(TD) 角を使ったメニュー (/TD)
(TD) 野菜を使ったメニュー (/TD)
(/TR) (/TABLE)
(UL)
(UI) 昨日のメニュー 〈/U)
(UI) 今日のメニュー 〈/U)
(UI) 明日のメニュー 〈/U)
(UI) 明日のメニュー 〈/U)
(VI) 明日のメニュー 〈/U)
```

【図11】



【図12】

```
我が家のレシピ集

| 肉を使ったメニュー | 野菜を使ったメニュー | 野菜を使ったメニュー | 中日のメニュー | ・ 中日のメニュー | ・ 中日のメニュー | ・ 中日のメニュー | ・ 明日のメニュー |
```

```
昨日のメニュー
- ごはん
- ご腐のお味噌汁
- 肉じゃが
- 小松菜のおひたし
```

【図13】

```
(HTML)
(BODY)
(CENTER) (HI) 我が家のレシピ集〈/HI〉 (/CENTER)
(TABLE BORDER COLS=3) (TR)
(TD) 肉を使ったメニュー (/TD)
(TD) 肉を使ったメニュー (/TD)
(TD) 野菜を使ったメニュー (/TD)
(/TR) (/TABLE)
(UL)
(UL)
(UL)
(UL) 昨日のメニュー (/LI)
(LI) 今日のメニュー (/LI)
(LI) 明日のメニュー (/LI)
(//UL)
(/BODY)
(/HTML)
```

```
(HTML)
(BODY)

昨日のメニュー
(UL)
(LI) ごはん (/LI)
(LI) 豆腐のお味噌汁 (/LI)
(LI) 肉じゃが (/LI)
(LI) 小松菜のおひたし (/LI)
(/BODY)
(/HTML)
```

### 【図14】

```
(HTML)
(BODY)
(CENTER) (HI) 我が家のレシピ集 (/HI) (/CENTER)
(TABLE BORDER COLS=3) (TR)
(TD) 肉も使ったメニュー (/TD)
(TD) 魚を使ったメニュー (/TD)
(TD) 野菜を使ったメニュー (/TD)
(/TR) (/TABLE)
(UL)
(LI) 昨日のメニュー (/LI)
(LI) 明日のメニュー (/LI)
(LI) 明日のメニュー (/LI)
(/UL)

昨日のメニュー
(UL)
(LI) ごはん (/LI)
(LI) ごはん (/LI)
(LI) 内心をが (/LI)
(LI) 内心をのおひたし (/LI)
(/UL)
(/BODY)
(/HTML)
```

ĩ